

# Análise de Viabilidade Econômica de Projetos de Geração Fotovoltaica com a Estimação de Índices Macroeconômicos por Redes Neurais Artificiais com Seleção de Atributos

Beatrice Silva de Almeida, Guilherme Guimarães Lage

**Resumo**—Projetos de grande porte de geração de energia fotovoltaica têm um tempo de retorno do investimento longo e esse tempo é definido com base em indicadores macroeconômicos que são variáveis no tempo, mas, que para fins de análise de viabilidade econômica, são considerados estáticos. Redes Neurais Artificiais (RNAs) têm se mostrado como uma ferramenta útil para análises financeiras e é possível encontrar na literatura correlata aplicações bem sucedidas para a estimação de preços de ações e índices baseadas na conjunção de uma combinação de dados e valores prévios. A partir dessas aplicações de RNAs, propõe-se neste trabalho de conclusão de curso o uso de RNAs perceptron multi-camadas com seleção de atributos para a estimação de índices macroeconômicos aplicados à análise de viabilidade econômica de projetos de geração fotovoltaica. Para isso, o *Correlation-Based Feature Selection* foi utilizado para selecionar os atributos mais relevantes para a entrada da RNA perceptron multi-camadas com retro-propagação e essa RNA foi empregada na estimação do Índice Nacional de Preços ao Consumidor Amplo (IPCA) ao longo do tempo para que este pudesse ser utilizado na análise de viabilidade econômica. Após o levantamento de dados e treinamento da RNA, esta apresentou um bom desempenho quanto ao modelo de predição e obteve um desempenho superior quando a seleção de atributos não foi considerada. No entanto, os erros, mesmo que pequenos, influenciam bastante a análise de viabilidade econômica, principalmente para horizontes de planejamento de curto e médio prazos, devido à relativamente recente base de dados para a elaboração deste modelo de estimação de índices macroeconômicos.

**Index Terms**—análise de viabilidade econômica, projetos de geração fotovoltaica, RNAs, seleção de atributos.

## I. INTRODUÇÃO

**G**ERAÇÃO de energia elétrica por meio do efeito fotovoltaico não é uma ideia nova. As primeiras observações do fenômeno fotovoltaico datam de 1839, feitas pelo físico francês Edmond Becquerel [1]. Entretanto, somente com a evolução tecnológica nas últimas décadas foi possível a democratização do acesso a essa fonte de geração de energia elétrica. Observa-se nesta última década uma expansão do mercado de energia elétrica fotovoltaica, com uso tanto em residências quanto comercial, incluindo investimentos em usinas de geração fotovoltaica.

Os custos desta forma geração diminuíram, porém ainda se trata de um investimento inicial alto. Para avaliar os custos e

benefícios da implantação de um projeto de geração fotovoltaica em uma empresa são realizadas análises de viabilidade técnica e econômica. Uma vez que a viabilidade técnica seja aprovada, passa-se à análise de viabilidade econômica do projeto. Essa análise considera riscos, custos e tempo de retorno que este investimento pode trazer para a empresa ao longo de um determinado horizonte.

São três os métodos mais difundidos de análise de viabilidade econômica: *payback time*, Valor Presente Líquido (VPL) e a Taxa Interna de Retorno (TIR). Alguns desses métodos possuem metas de lucro, que são definidas pela política interna de cada empresa [2]. Nestes casos, a inflação é um importante índice macroeconômico a ser levado em consideração nessas análises, pois ela define a desvalorização do dinheiro ao longo do tempo e também é um dos indicadores que compõem o cálculo do aumento das tarifas de energia elétrica. O cálculo desse reajuste é de responsabilidade da Agência Nacional de Energia Elétrica (ANEEL), órgão autárquico vinculado ao Ministério de Minas e Energia (MME) responsável pela fiscalização do setor elétrico brasileiro [3].

O Índice Nacional de Preços ao Consumidor Amplo (IPCA) é o indicador base da inflação no Brasil. Existem várias metodologias para determinar o IPCA e como devem ser definidas as políticas financeiras de Estado para manter a inflação sob controle. Outra parte dos estudos financeiros acerca da inflação propõe estratégias de estimação desse índice para que as tomadas de decisões financeiras sejam feitas de maneira a minimizar os riscos de se perder dinheiro ou para a prospecção de oportunidades de investimento.

Devido à capacidade das RNAs modelagem de fenômenos não lineares, encontra-se na literatura correlata estudos realizados para o emprego dessa abordagem à estimação do IPCA. Em [4], o autor se baseou nesse fato para implementar uma RNA para a modelagem da curva de Phillips (conceito econômico que se refere à correlação negativa existente entre a inflação e o desemprego e que significa que, quando há aumento em um desses indicadores, o outro tende a sofrer uma redução, e vice-versa), tendo por objetivo desenvolver uma abordagem evolutiva de estimação da inflação no Brasil. Nesse trabalho, observou-se que o desempenho das RNAs foi superior ao método linear quando tiveram seus critérios de Raiz do Erro Quadrático Médio de Previsão (REQMP) e de Erro Absoluto Médio de Previsão (EAMP) comparados. Ainda é mencionado, nesse mesmo trabalho, que não é habitual estimar

o valor exato do IPCA devido ao seu comportamento distinto, que é influenciado por regras de contratos de indexação.

Em [5], RNAs foram usadas para realizar a estimação dos núcleos de inflação tradicionalmente utilizados pelo Banco Central do Brasil (BACEN). Também foram estimados os núcleos de inflação utilizando wavelets para efeitos de comparação de resultados. Wavelets são um tipo de transformação em bases ortonormais que podem ser utilizadas para representar funções e têm sido consideradas como um bom meio para filtrar ruídos nesses tipos de estimações. Nesse trabalho foi observado que a estimação dos núcleos de inflação usando a combinação de wavelets e RNAs obteve um melhor desempenho para a estimação do IPCA do que os núcleos normalmente utilizados pelo BACEN.

RNAs perceptron multi-camadas também já foram utilizadas para a predição do IPCA em [6]. Através de análises econométricas escolheu-se três variáveis que compuseram três modelos de predição do IPCA. O primeiro modelo utilizou a curva de Phillips junto com a primeira diferença da taxa de desemprego, defasagem de primeira ordem do IPCA, defasagem de primeira ordem do hiato do produto e defasagem de segunda ordem da variação cambial. O segundo modelo considerou a defasagem de primeira ordem do produto, as metas de inflação, defasagem de primeira ordem da Selic, defasagem de primeira ordem do IPCA e defasagem de primeira ordem da variação cambial. O último modelo utilizou a defasagem de primeira ordem do IPCA para comparar com os resultados preditos através do modelo Auto-Regressivo Integrado de Médias Móveis (ARIMA, sigla em inglês para *autoregressive integrated moving average*). O trabalho citado concluiu que, apesar dos resultados da RNA serem adequados, o modelo ARIMA mostrou resultados mais eficientes na estimação do IPCA.

A inflação é governada por vários indicadores macroeconômicos, por isso este trabalho de conclusão de curso propõe a análise de uma estratégia para a estimação do IPCA por RNAs baseada no comportamento variacional prévio de alguns desses indicadores. A utilização de RNAs se apresenta como uma possível abordagem porque são muitos os fatores externos que influenciam tanto a inflação quanto os outros indicadores macroeconômicos. As RNAs são amplamente utilizadas nesse escopo dada sua capacidade de aprendizado e generalização de problemas não lineares. Neste trabalho, opta-se por estudar o desempenho de uma RNA perceptron multi-camadas usando a retro-propagação (ou *backpropagation*) como algoritmo de treinamento. Esse tipo de arquitetura tem muitas aplicações bem documentadas na literatura correlata e um amplo suporte no ajuste de seus parâmetros de configuração para tornar seu desempenho mais eficiente.

Para atingir esse objetivo, foi levantado um conjunto de dados constituído por indicadores macroeconômicos, obtidos por fontes governamentais e do mercado financeiro, além de algumas das médias móveis do IPCA. A partir disso, procurou-se selecionar as variáveis mais relevantes através do método *Correlation Based Feature Selection*. Após a seleção de atributos as variáveis escolhidas foram utilizadas para fazer a previsão do IPCA nos horizontes de um, três, cinco e dez anos. Também foram realizados testes para se determinar,

de forma empírica, a arquitetura da RNA perceptron multi-camadas, sendo selecionada aquela que apresentou o melhor desempenho. Como forma de avaliação da RNA perceptron multi-camadas optou-se pelas métricas de Erro Quadrático Médio (EQM) e Erro Absoluto Médio (EAM) para comparar os resultados previstos com os resultados esperados. O intuito dessa estimativa é poder melhor direcionar o dimensionamento da Taxa Mínima de Atratividade (TMA) da análise de viabilidade econômica dos projetos de geração fotovoltaica, proporcionando uma melhor dimensão da expectativa de retorno do investimento. Para efeitos de comparação, além das projeções de análise de viabilidade econômica considerando-se a previsão desse índice, também foram calculadas as projeções da análise de viabilidade econômica considerando-se uma taxa de oportunidade estática (fixa).

O restante deste trabalho de conclusão de curso está organizado da seguinte forma. Na Seção II é realizada uma breve explicação sobre métodos para a análise de viabilidade econômica de projetos de investimento. Na Seção III é apresentada a metodologia de seleção de atributos e estimação do índice macroeconômico IPCA por RNAs. Os resultados numéricos obtidos para a análise de viabilidade econômica de projetos de geração fotovoltaica são apresentados na Seção IV. Na Seção V são apresentadas as principais conclusões deste trabalho de conclusão de curso.

## II. ANÁLISE DE VIABILIDADE ECONÔMICA

A determinação da estrutura ótima de capital é conhecida como um verdadeiro quebra cabeças na literatura financeira, e tem evidentes implicações na utilização do custo do capital para a decisão de implementação de projetos de investimento. O método do *payback time* é considerado apenas um método de apoio para a tomada de decisão de projetos de investimento, dado que seu resultado permite uma análise basicamente subjetiva. Considera-se, de fato, que os métodos ou critérios mais recomendados e utilizados para a análise de viabilidade econômica na implementação de projetos de investimento sejam o método do VPL e o método TIR [7].

### A. Payback Time

O método do *payback time* determina o tempo de recuperação do capital inicial investido. Após esse tempo, o retorno que o projeto oferece não é mais levado em consideração. O tempo é o grande fator dessa análise, sendo que quanto maior for esse tempo de retorno, maior será o risco associado à implementação do projeto de investimento. Atualmente, o *payback time* é mais utilizado como um método de apoio, porém ainda é muito popular em grandes empresas e seu resultado consiste em um critério bastante subjetivo para a tomada de decisão de implementação de um projeto de investimento [8]. De forma geral, o *payback time* é calculado como:

$$PP = \frac{I}{FC} \quad (1)$$

onde *PP* é o *payback period*, *I* é o investimento inicial, e *FC* é o fluxo de caixa anual esperado.

### B. Valor Presente Líquido

O método do VPL consiste em avaliar a diferença entre os valores das receitas e o valor dos custos. De forma geral, o VPL é calculado como:

$$VPL = \sum_{j=0}^n \frac{R_j}{(1+i)^j} - \sum_{j=0}^n \frac{C_j}{(1+i)^j} \quad (2)$$

onde  $R_j$  é o valor das receitas atuais,  $C_j$  é o valor dos custos;  $i$  é a taxa de juros,  $j$  é o período referente ao qual as receitas e os custos ocorrem, e  $n$  é o número de períodos ou duração do projeto.

Os critérios para a avaliação da viabilidade econômica de implementação do projeto de investimento se baseiam no valor do VPL. Se  $VPL > 0$ , o projeto de investimento é economicamente viável; caso contrário, se  $VPL < 0$ , o projeto de investimento não é economicamente atrativo. Para que o método seja aplicado corretamente é necessário que  $i$  para cada período  $j$  seja conhecido.

A TMA geralmente é definida por políticas internas da empresa. Porém, remete a um valor que leva em consideração o custo que um investimento acarreta à essa mesma empresa [7].

### C. Taxa Interna de Retorno

A TIR é a taxa de juros que iguala o valor presente previsto das entradas de caixa com o valor presente das saídas de caixa em uma determinada data. Em outras palavras, é a taxa de referência para quando o VPL apresenta valor 0. Seu resultado é expresso em forma de porcentagem. Esse tipo de método pressupõe riscos iguais aos projetos analisados, o que pode não ser uma premissa verdadeira [8].

$$i = \sum_{j=1}^n \frac{FC_j}{(1+TIR)^j} \quad (3)$$

O gráfico da Figura 1 ilustra a relação entre o VPL e a TMA, onde a TIR é determinada a partir da interceptação da curva com o eixo TMA.




Figura 1. Relação entre o VPL e a TMA.

### D. Inflação

A política vigente de inflação no Brasil foi adotada oficialmente em meados de 1999 através de decreto presidencial. Esse decreto tinha como objetivo fixar níveis para a inflação com base nas variações anuais de um índice de preço conhecido, deixar a cargo do Conselho Monetário Nacional (CMN) a estipulação das metas de inflação e incumbir ao BACEN a tarefa de que essas metas fossem cumpridas, utilizando para isso os instrumentos necessários. No ano de 1999 o CMN determinou que o índice que seria utilizado como referência para o regime de metas da inflação seria o IPCA [9].

O instrumento escolhido para fazer o controle da inflação foi o a taxa de juros do Sistema Especial de Liquidação e Custódia (Selic). A Selic é a taxa que serve de referência para os juros da economia brasileira, que baliza as trocas de reservas entre as instituições financeiras e é considerada pelo mercado como o principal indicador de política monetária do governo [10].

### III. METODOLOGIA PARA A SELEÇÃO DE ATRIBUTOS E ESTIMAÇÃO DO IPCA POR RNAs

Há vários métodos que podem ser empregados para a estimação de séries temporais, como é o caso do IPCA. Uma das formas de fazer esse tipo de estimação é a utilização de redes recorrentes para correlacionar valores prévios do IPCA com outros indicadores. Porém dado que as redes *Long Short-term Memory* são mais complexas de se implementar e podem resultar em maiores erros para a estimação, optou-se por desenvolver este trabalho de conclusão de curso com uma RNA perceptron multi-camadas. A decisão pela escolha de uma RNA perceptron multi-camadas se deveu ao fato de esta ser uma rede com um forte desempenho em solução de problemas complexos, onde não há um conhecimento exato da dinâmica entre seus parâmetros de entrada e a saída esperada.

#### A. Ambiente de Programação para a Implementação das RNAs

A linguagem de programação escolhida para esta aplicação foi *Python*. Esta linguagem é amplamente utilizada para aplicações de aprendizado de máquinas. Uma de suas vantagens é a grande disponibilidade de bibliotecas já implementadas para o desenvolvimento de RNAs. Para o desenvolvimento deste trabalho foram utilizadas as bibliotecas *pandas*, *numpy*, *sklearn* e *keras*.

O ambiente computacional utilizado foi o *jupyter notebook*, que permite o desenvolvimento de software de código aberto baseados em linguagens de programação, dentre elas *Python*.

#### B. Levantamento de Dados para a Estimação do IPCA

Para a estimação do IPCA neste trabalho de conclusão de curso foram selecionados dados relacionados à macroeconomia do país. A macroeconomia pode ser definida como o estudo da economia como um todo, observando o comportamento de grandes agregados, por exemplo: nível geral de preços, emprego e desemprego, estoque de moedas, renda e produtos nacionais, taxas de juros e taxa de câmbio [11]. Esses

dados possuem amostragem mensal ou diária. O conjunto de dados utilizado foi indexado por índices diários; dados com amostragem mensal foram replicados dentro do respectivo período mensal e indexados junto aos índices diários.

No total foram levantados 27 atributos: IGP-M, taxa de juros Selic, taxa de juros futuros DI, cotação do euro, cotação do dólar, salário mínimo, PIB do Brasil, consumo de energia elétrica, estoque de empregos formais, taxa de desemprego, índices da bolsa de valores brasileira B3 (volume, max, min, abertura e fechamento), índice do petróleo (volume, max, min, abertura e fechamento) e as médias móveis do IPCA. Foram calculadas médias móveis para um ano, dois, cinco e dez anos para a série histórica do IPCA.

Por causa da discrepância das grandezas de cada atributo foi necessário realizar uma normalização de seus valores. Essa normalização impede que RNAs façam associações imprecisas entre atributos correlacionados, porém com valores discrepantes. Os atributos foram normalizados entre -1 e 1 através da biblioteca *sklearn*.

### C. Seleção de Atributos

A seleção de atributos é utilizada para se determinar o conjunto de dados de entrada que mais influenciam no resultado da RNA, buscando a melhora no resultado da estimação da rede. Para isso, foi utilizado o método de seleção de atributos que se baseia na correlação entre os atributos definidos no levantamento de dados para a estimação do IPCA. O *Correlation-Based Feature Selection* (CFS) foi proposto por [12] e pode ser aplicado para conjuntos de dados tanto contínuos como discretos. Esse método avalia o peso de um subgrupo de atributos considerando a capacidade de predição individual de cada variável [12].

A seleção de atributos foi realizada através do software *Waikato Environment for Knowledge Analysis* (WEKA), que contém vários algoritmos para a mineração de dados, entre eles o CFS. Nele foram inseridos todos os 27 atributos do conjunto de dados e escolheu-se como método de seleção o *CfsSubsetEval*, e como método de procura o *BestFirst* [13].

### D. Métricas de Avaliação

A partir de um conjunto de previsões feitos pelo modelo criado é possível compará-los aos resultados esperados e assim observar o desempenho da perceptron multi-camadas. As métricas de avaliação foram o EQM e o EAM.

1) *Erro Quadrático Médio*: o EQM consiste na média do somatório da diferença ao quadrado entre o valor observado e o valor previsto. Quanto mais próximo de 0, melhor é o desempenho da perceptron multi-camada. Por causa do quadrado da diferença, desvios maiores terão maior influência nessa métrica. Pode-se descrever seu cálculo conforme a equação abaixo:

$$EQM = \frac{1}{n} \sum_{i=1}^n (y_o - y_e)^2 \quad (4)$$

onde  $n$  é o número de observações,  $y_o$  é a saída esperada e  $y_e$  é a saída estimada pela rede neural.

2) *Erro Absoluto Médio*: o EAM consiste na média do somatório do módulo da diferença entre o valor observado e o valor previsto. Essa métrica atribui o mesmo pesos aos desvios, como pode ser observado na equação.

$$EAM = \frac{1}{n} \sum_{i=1}^n |y_o - y_e| \quad (5)$$

onde  $n$  é o número de observações,  $y_o$  é a saída esperada e  $y_e$  é a saída estimada pela rede neural.

### E. Redes Neurais Artificiais

As RNAs tiveram sua criação inspirada na modelagem matemática do comportamento do neurônio humano. A partir disso, nasceu um campo de pesquisa muito vasto. Basicamente uma RNA tenta imitar a maneira como o cérebro humano aprende e executa uma tarefa [14]. O modelo matemático de um neurônio, proposto por Warren McCulloch e Walter Pitts, pode ser descrito como um conjunto de  $n$  entradas que são multiplicadas por pesos  $w$  e, em seguida, são somados a um *bias*  $b$  e comparados com um limiar (função de ativação) [15]. O treinamento de uma RNA consiste, portanto, em determinar todos os valores de  $w$  para todas as ligações sinápticas e todos os valores de  $b$  para todos os neurônios da RNA de forma que a combinação dos dados de entrada da rede resultem em uma saída determinada. A Figura 2 representa a modelagem de um neurônio artificial.




Figura 2. Representação do modelo matemático de um neurônio artificial [16].

Ao analisarem o perceptron, Minsky e Papert em [17] concluíram que esse tipo de rede, com apenas uma camada, não era capaz de resolver problemas que não fossem linearmente separáveis. Na época não havia um método eficiente para treinar redes multi-camadas, logo as pesquisas nesta área estagnaram.

Na década de 1980, com o desenvolvimento do algoritmo de treinamento por retro-propagação por Rumelhart, Hinton e Williams em [18] ficou demonstrado que era possível treinar redes com camadas intermediárias. A RNA perceptron multi-camadas com o treinamento por retro-propagação tornou-se, então, um dos tipos de rede mais populares, sendo utilizada para várias finalidades.

Uma RNA perceptron multi-camadas é composta por uma camada de entrada, que recebe as informações; uma ou mais camadas intermediárias, composta por um número indeterminado de neurônios; e a camada de saída, onde podemos

observar o resultado estimado pela RNA. A Figura 3 apresenta o esquema de uma RNA perceptron multi-camadas.




Figura 3. Modelo de RNA perceptron multi-camadas.

Com essa possibilidade de organização de RNAs em múltiplas camadas, passou a ser possível o seu uso para a resolução de problemas mais complexos e de natureza não linear.

1) *Funções de Ativação:* Para as camadas intermediárias (ocultas) da perceptron multi-camadas, foi escolhida a função de ativação ReLu [19]. Essa função é uma das mais utilizadas atualmente. Sua ativação ocorre quando os valores são positivos ou retorna 0 quando o resultado são valores negativos. A escolha da função de ativação foi feita com base no estudo do conjunto de dados, onde foi observado que a função de ativação ReLu retornava melhores resultados. A função de ativação ReLu pode ser matematicamente expressa como:

$$\sigma(x) = \max(0, x) \quad (6)$$

Na camada de saída utilizou-se a função de ativação linear, dada por:

$$\sigma(x) = x \quad (7)$$

A função linear não altera o resultado da saída. Geralmente é considerada na camada de saída das RNAs para problemas de regressão, como o proposto neste trabalho de conclusão de curso.

2) *Perceptron Multi-Camadas:* A implementação da RNA para este trabalho de conclusão de curso foi feita através da biblioteca *keras*, que possui uma ampla documentação sobre vários métodos para RNAs. O conjunto de dados foi dividido da seguinte maneira: 80% para treinamento da rede e 20% para a validação da rede. De modo empírico foram testadas algumas configurações da perceptron multi-camadas para a obter aquela que resultasse em um melhor desempenho para esta aplicação.

Para se determinar o número de neurônios que seriam utilizados na primeira camada intermediária, a perceptron multi-camadas foi executada nove vezes acrescentado cinco neurônios a cada nova configuração. As Tabela I mostra o

Tabela I  
EQM E EAM EM FUNÇÃO DO NÚMERO DE NEURÔNIOS NA PRIMEIRA CAMADA INTERMEDIÁRIA

Número de Neurônios	Tempo [s]	EQM	EAM
5	13,67	0,0111	0,0842
10	61,38	0,0077	0,0685
15	25,13	0,0071	0,0667
20	46,46	0,0062	0,0597
25	76,56	0,0035	0,0461
30	70,48	0,0059	0,0607
35	73,57	0,0033	0,0444
40	58,28	0,0046	0,0530
45	55,17	0,0041	0,0478

EQM e o EAM de cada execução em função do número de neurônios.

Como pode ser observado na Tabela I, 35 neurônios na primeira camada intermediária resulta nos menores erros. Porém, ao se comparar os erros das RNAs com 25 e 35 neurônios na primeira camada intermediária, não é verificada uma melhora significativa. Logo, optou-se por utilizar 25 neurônios na primeira camada intermediária.

Após a definição do número de neurônios da primeira camada intermediária, foi investigado como a RNA responderia à adição de uma segunda camada intermediária. Para tanto, a perceptron multi-camadas foi implementada com uma segunda camada intermediária; para cada execução dessa configuração foi efetuada a adição de 5 neurônios conforme proposto para a primeira camada intermediária. A Tabela II mostra o EQM e o EAM de cada execução em função do número de neurônios.

Tabela II  
EQM E EAM EM FUNÇÃO DO NÚMERO DE NEURÔNIOS NA SEGUNDA CAMADA INTERMEDIÁRIA

Número de Neurônios	Tempo [s]	EQM	EAM
5	45,16	0,00291	0,04136
10	30,37	0,00316	0,04587
15	25,37	0,00265	0,04132
20	43,16	0,00260	0,04139
25	32,05	0,00244	0,04049
30	37,30	0,00206	0,03527
35	18,91	0,00268	0,03999
40	31,52	0,00300	0,04260
45	44,65	0,00163	0,03240

Como pode ser notado, a adição de uma segunda camada levou a um melhor desempenho da perceptron multi-camadas. Com 35 neurônios observa-se que o EQM foi significativamente menor em comparação aos erros da perceptron multi-camadas com apenas uma primeira camada intermediária. Por este motivo foi escolhido adicionar uma segunda camada, com 35 neurônios. Não foi escolhido um número maior de neurônios porque a redução do erro foi pouca em comparação aos 35.

A quantidade de épocas para o treinamento da RNA perceptron multi-camadas foi determinada como 1000. Não foi necessário aumentar esse valor, pois durante execução do algoritmo de treinamento os critérios de parada eram atingidos antes das 1000 épocas.

Tabela III  
VALORES PARA CÁLCULO DO CONSUMO MENSAL DE ENERGIA ELÉTRICA

Porcentagem de Consumo no Período	Potência [W]	Número de Horas por Dia	Dias no Mês	Energia Consumida no Mês [MWh]
85%	24714,6	9	30	6,67
100%	29076	15	30	13,08

Tabela IV  
CUSTOS DO PROJETO DE GERAÇÃO FOTOVOLTAICA

Item	Quantidade	Unidade S.I.	Valor Unitário [R\$]	Totais [R\$]
Cabo 6 mm	3780	metro	5,85	22.113,00
Cabo 10 mm	1440	metro	10,41	14.990,4
Placa solar	675	unidade	1.016,64	686.232,00
Inversor	9	unidade	30.710,40	276.393,60
Disjuntor	9	unidade	144,30	1.298,70
Despesas extras 5%	1	porcentagem	50.051,39	50.051,39
Valor total do Projeto				1.051.079,09

3) *Treinamento pelo Algoritmo de Retro-Propagação*: Esse método retro propaga o erro entre a saída calculada e a esperada. Esta diferença é usada no ajuste dos pesos sinápticos  $w$  e dos bias  $b$  dos neurônios artificiais. O processo é repetido sucessivamente (épocas) até que o erro na camada de saída esteja dentro de um valor predeterminado [20], [21].

Como parte do processo de otimização minimização entre a saída calculada e a esperada da perceptron multi-camadas foi utilizado o algoritmo *Adaptive Moment Estimation* (Adam). Nesse algoritmo, os pesos sinápticos são ajustados pela descida do gradiente estocástica [22], [23]. O algoritmo Adam foi escolhido por apresentar os melhores resultados para esta arquitetura de RNA.

Com o intuito de evitar o *overfitting*, também foi considerado um critério de parada antecipada, o *EarlyStopping*. O *EarlyStopping* foi configurado para monitorar a “perda” em cada época de treinamento, de maneira a garantir que ela fosse mínima. Para evitar a perda de possíveis melhoras no desempenho foi também estabelecida uma tolerância de 10 épocas. Este recurso foi utilizado junto com o *ReduceLROnPlateau*, sendo este utilizado para verificar se o desempenho da rede atingiu um platô de melhora. Quando essa condição é observada e não há a melhora da métrica após um número determinado de épocas (*patience*), a taxa de aprendizado é diminuída para 0.85 do valor anterior. Os modelos geralmente apresentam melhoras no desempenho com a utilização deste recurso [24].

#### IV. RESULTADOS E DISCUSSÕES

##### A. Análise de Viabilidade Econômica

Para esta análise utilizou-se um levantamento técnico da carga de iluminação de uma planta industrial do interior do Estado de São Paulo e a viabilidade técnica da instalação de painéis fotovoltaicos para o suprimento de energia desta indústria [25]. Esse estudo utilizou duas formas de análise de viabilidade econômica para se determinar a viabilidade de implementação desse projeto de investimento: *payback time* e o VPL. No referido estudo de caso, a carga de iluminação constitui-se em lâmpadas fluorescentes que, das 8h às 17h, opera com 100% da carga instalada e, das 18h às 7h, opera com 85% da carga instalada.

Com base na Tabela III e nas tarifas de energia praticadas no ano de 2015, foi calculado o gasto mensal com a iluminação desta instalação. Essa planta industrial adquire energia através do mercado livre de energia, e no ano de 2015 o preço do MWh era de R\$ 252,00. Considerando-se a demanda de 19,76 MWh, o gasto mensal com a iluminação era de R\$ 4.978,80 por mês.

De acordo com [25], as principais características do sistema de geração fotovoltaica a ser implementado são: um sistema modular, composto por 675 painéis de 255 Wp e 9 inversores de potência nominal de 20 kW cujo valor do investimento é dado por R\$ 1.051.079,09.

Definidas as especificações técnicas do projeto de investimento, também foi definido o orçamento desse projeto como pode ser observado na Tabela IV.

Todos os valores levantados na Tabela IV se referem ao ano de 2016. Utilizaram-se esses valores de forma a possibilitar a comparação das análises de viabilidade econômica em [25] e o presente trabalho de conclusão de curso.

1) *Payback Time*: Este método de análise é menos complexo de ser calculado. São levantadas as entradas e as saídas do projeto. O custo do projeto é considerado como investimento inicial e a economia da energia gerada pela geração fotovoltaica foi considerado como lucro. Também foi considerado um ajuste de 10,36% por ano na tarifa de energia [25].

O cálculo do *payback time* pode ser observado na Tabela V que mostra o fluxo de caixa. Nessas condições, o tempo de retorno desse investimento é estimado em aproximadamente 10 anos e meio. Não é um período muito longo, mas dado as incertezas em torno dos dados macroeconômicos durante esse período, trata-se de uma análise de viabilidade econômica cuja aplicabilidade prática é bastante subjetiva.

2) *Valor Presente Líquido*: O cálculo do VPL envolve critérios que fornecem maior segurança para a análise de viabilidade econômica, por isso é bastante utilizado por empresas de grande porte. Considera-se a inflação, a expectativa de vida útil dos equipamentos e também é calculado um índice de deterioração dos equipamentos investidos. A depreciação foi calculada com o método das somas dos dígitos. Também foi



Tabela V  
FLUXO DE CAIXA PARA O CÁLCULO DO TEMPO DE RETORNO DO INVESTIMENTO PELO MÉTODO DO PAYBACK TIME

Ano	Entrada [R\$]	Saldo Inicial [R\$]	Saldo Final [R\$]	Coefficiente de Payback
1	59.391,36	-1.051.079,09	-991.687,73	1
2	65.538,37	-991.687,73	-926.149,36	1
3	72.321,59	-926.149,36	-853.827,77	1
4	79.806,87	-853.827,77	-774.020,90	1
5	88.066,88	-774.020,90	-685.954,02	1
6	97.181,80	-685.954,02	-588.772,22	1
7	107.240,12	-588.772,22	-481.532,09	1
8	118.339,47	-481.532,09	-363.192,62	1
9	130.587,61	-363.192,62	-232.605,01	1
10	144.103,43	-232.605,01	-88.501,59	1
11	159.018,13	-88.501,59	70.516,55	0,56
12	175.476,51	70.516,55	245.993,05	0
13	193.638,33	245.993,05	439.631,38	0
14	213.679,89	439.631,38	653.311,27	0
15	235.795,76	653.311,27	889.107,03	0

Tabela VI  
VALORES CONSIDERADOS PARA A DEPRECIÇÃO DO SISTEMA DE GERAÇÃO FOTOVOLTAICA

Vida Útil	Depreciação [R\$]
25	80.852,24
24	77.618,15
23	74.384,06
22	71.149,97
21	67.915,88
20	64.681,79
19	61.447,70
18	58.213,61
17	54.979,52
16	51.745,43
15	48.511,34
14	45.277,25
13	42.043,16
12	38.809,07
11	35.574,98
10	32.340,89
9	29.106,81
8	25.872,72
7	22.638,63
6	19.404,54
5	16.170,45
4	12.936,36
3	9.702,27
2	6.468,18
1	3.234,0

determinado um período de 25 anos de vida útil do sistema e considerado um custo de oportunidade como 8%.

Na Tabela VI é mostrado como o valor do sistema de geração fotovoltaica deprecia em função do tempo, e na Tabela VII pode-se observar o fluxo de caixa ao longo do tempo. Nas condições descritas, tem-se que o tempo de retorno do investimento calculado por esse método se torna de aproximadamente 25 anos e 3 meses. Dado que a vida útil do sistema de geração fotovoltaica é de 25 anos, considera-se que este é um investimento que não agrega valor à empresa e, portanto, é desaconselhada a sua implementação.

**B. Estimação do IPCA por RNAs com Seleção de Atributos**

1) *Seleção de Atributos:* A seleção de atributos retornou cinco variáveis que tinham maior influência na estimação do

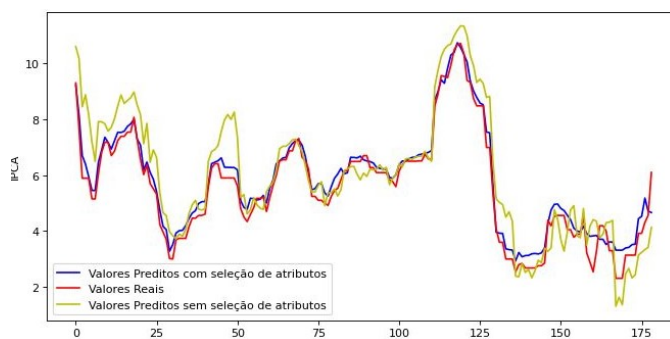


Figura 4. Comparação da estimação do IPCA por RNAs considerando-se conjuntos de dados de entrada com e sem a seleção de atributos.




Figura 5. Gráfico do EQM ao longo das épocas do treinamento da RNA perceptron multi-camadas.

IPCA conforme o banco de dados levantado. Essas variáveis foram: taxa de juros Selic, taxa de juros futuros DI, taxa de desemprego, média móvel do IPCA de um ano, e média móvel do IPCA de dois anos.

Para avaliar a eficiência da seleção de atributos primeiro executou-se a perceptron multi-camadas usando o conjunto de dados com os atributos selecionados e depois com o conjunto de dados sem a seleção de atributos. Na Figura 4 pode-se observar o desempenho de cada conjunto de dados. Observou-se que o EQM e o EAM foram, respectivamente, 0,01283 e 0,08646 para o conjunto sem a seleção de atributos; já com a seleção de atributos o EQM e o EAM apurados foram, respectivamente, de 0,00216 e 0,03749. Com base nos erros é mostrado que a seleção de atributos influenciou de maneira positiva os resultando e dispondo-se de menos atributos, dispensa-se o processamento de variáveis desnecessárias.

2) *RNA Perceptron Multi-Camadas:* Com o banco de dados já alterado pela seleção de atributos executou-se o modelo da perceptron multi-camadas. A Figura 5 mostra o EQM ao longo das épocas do treinamento da RNA perceptron multi-camadas.

Inicialmente, mediu-se sua capacidade de generalização da RNA. Para isso foram escolhidos 180 pontos de maneira aleatória para servir como conjunto de teste. A Figura 6 apresenta a comparação entre os dados reais e os valores previstos pela RNA perceptron multi-camadas.

Como pode ser visto, a RNA perceptron multi-camadas acompanha satisfatoriamente a curva dos dados reais. Neste caso, o EQM da estimação foi 0,00243 e o EAM foi

Tabela VII  
FLUXO DE CAIXA PARA O CÁLCULO DO TEMPO DE RETORNO DO INVESTIMENTO PELO MÉTODO DO VALOR PRESENTE LÍQUIDO

Ano	Queda de Eficiência [R\$]	Economia [R\$]	Depreciação [R\$]	Valor Operacional [R\$]	VPL do Valor Operacional [R\$]	VPL Acumulado [R\$]	Coefficiente de Payback
1	100,0	59.391,36	80.852,24	-21.460,88	-19.871,18	-1.070.950,27	1,0
2	99,2	65.014,06	77.618,15	-12.604,09	-10.805,97	-1.081.756,24	1,0
3	98,4	71.164,44	74.384,06	-3.219,62	-2.555,84	-1.084.312,08	1,0
4	97,6	77.891,51	71.149,97	6.741,54	4.955,23	-1.079.356,85	1,0
5	96,8	85.248,74	67.915,88	17.332,86	11.796,45	-1.067.560,39	1,0
6	96,0	93.294,53	64.681,79	28.612,74	18.030,88	-1.049.529,51	1,0
7	95,2	102.092,60	61.447,70	40.644,89	23.715,91	-1.025.813,61	1,0
8	94,4	111.712,46	58.213,61	53.498,85	28.903,77	-996.909,84	1,0
9	93,6	122.230,00	54.979,52	67.250,48	33.641,98	-963.267,86	1,0
10	92,8	133.727,98	51.745,43	81.982,55	37.973,78	-925.294,07	1,0
11	92,0	146.296,68	48.511,34	97.785,34	41.938,46	-883.355,62	1,0
12	91,2	160.034,58	45.277,25	114.757,32	45.571,71	-837.783,91	1,0
13	90,4	175.049,05	42.043,16	133.005,88	48.905,99	-788.877,92	1,0
14	89,6	191.457,18	38.809,07	152.648,11	51.970,73	-736.907,19	1,0
15	88,8	209.386,64	35.574,98	173.811,65	54.792,68	-682.114,50	1,0
16	88,0	228.976,55	32.340,89	196.635,65	57.396,07	-624.718,43	1,0
17	87,2	250.378,57	29.106,81	221.271,76	59.802,89	-564.915,54	1,0
18	86,4	273.757,96	25.872,72	247.885,24	62.033,04	-502.882,50	1,0
19	85,6	299.294,76	22.638,63	276.656,13	64.104,56	-438.777,94	1,0
20	84,8	327.185,11	19.404,54	307.780,58	66.033,77	-372.744,17	1,0
21	84,0	357.642,65	16.170,45	341.472,20	67.835,42	-304.908,75	1,0
22	83,2	390.900,01	12.936,36	377.963,65	69.522,83	-235.385,93	1,0
23	82,4	427.210,49	9.702,27	417.508,22	71.108,03	-164.277,89	1,0
24	81,6	466.849,82	6.468,18	460.381,64	72.601,88	-91.676,02	1,0
25	80,8	510.118,10	3.234,09	506.884,01	74.014,14	-17.661,88	1,0
26	80,0	557.341,90	0,00	557.341,90	75.353,61	57.691,73	0,2




Figura 6. Comparação entre dados reais e estimados pela RNA perceptron multi-camadas.

de 0,04048. Esses erros são considerados baixos e mostram que a rede responde bem ao treinamento.

O próximo passo dado foi observar como a rede se comportava para estimações com horizontes mais longos. Foram feitas estimações para um, três, cinco e dez anos. Para realizar essas estimações, o conjunto de dados de entrada foi ajustado para que a validação da RNA perceptron multi-camadas abarcasse esses limites de tempo. A comparação entre os valores reais e os estimados são mostrados nas Figuras 7, 8, 9 e 10.

Para a estimacão no horizonte de um ano, a RNA perceptron multi-camadas não foi muito precisa na estimacão do IPCA como pode ser observado na Figura 7. O EQM e o EAM para essa estimacão foram, respectivamente, 0,1826 e 0,3940. Outro fator observado que desfavorece esse horizonte de estimacão é que a curva não acompanha a tendéncia dos valores reais, revelando ser pouco confiável essa estimacão.

Para a estimacão no horizonte de três anos, a RNA perceptron multi-camadas também não foi muito precisa na

estimacão do IPCA como pode ser observado na Figura 8. O EQM e o EAM para essa estimacão foram, respectivamente, 0,3733 e 0,4938.

Para a estimacão no horizonte de cinco anos, a RNA perceptron multi-camadas foi significativamente mais precisa na estimacão do IPCA que nos casos anteriores como pode ser observado na Figura 9, pois a curva acompanha a tendéncia do IPCA ao longo do tempo. Apesar de não ser uma correspondéncia perfeita, é possível reparar uma melhora significativa nesta previsão. O EQM e o EAM para essa estimacão foram, respectivamente, 0,03204 e 0,1528.

Para a estimacão no horizonte de dez anos, pode-se observar na Figura 10 que a curva dos resultados estimados acompanha a curva dos resultados reais, ainda que de modo impreciso, mas que prevê suas tendéncias de crescimento e decréscimo. No entanto, em alguns pontos, ainda existe uma discordância que pode ser causada por atributos não considerados no levantamento de dados e que são, portanto, imprevisíveis para esta rede. Essa falha acontece, pois a economia reflete uma gama de políticas adotadas pelo Estado que nem sempre acompanham a tendéncia das variáveis utilizadas para a estimacão. Apesar desses pontos dissonantes, o EQM e o EAM foram baixos e iguais a 0,0561 e 0,1830, respectivamente.

### C. Análise de Viabilidade Econômica com a Estimacão do IPCA por RNAs com Seleção de Atributos

Por fim, nesta subseção será calculado o VPL do projeto de investimento considerando como custo de oportunidade o IPCA estimado pela RNA perceptron multi-camadas com seleção de atributos. Para isso é considerada no cálculo a média aritmética do IPCA anual ao longo dos anos de 2016 a 2021. Como a RNA perceptron multi-camadas não suporta a



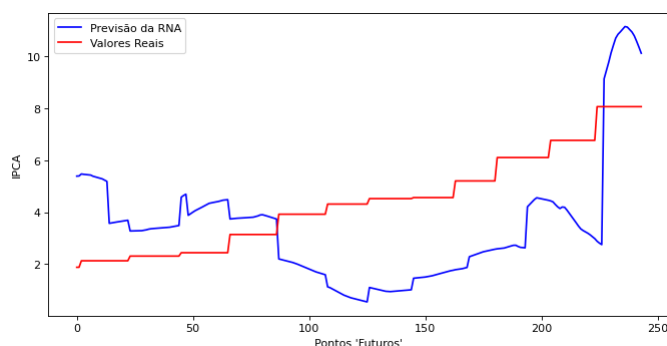


Figura 7. Comparação entre os resultados reais e estimados para o horizonte de um ano.




Figura 9. Comparação entre os resultados reais e estimados para o horizonte de cinco anos.




Figura 8. Comparação entre os resultados reais e estimados para o horizonte de três anos.

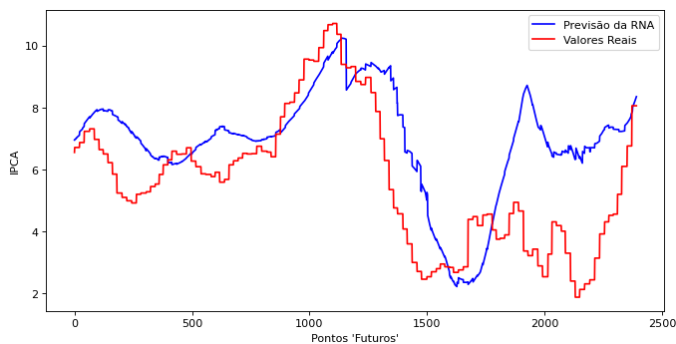


Figura 10. Comparação entre os resultados reais e estimados para o horizonte de dez anos.

estimação para um horizonte maior que dez anos, esse será o limite de cálculo da análise de viabilidade econômica.

A partir da Tabela VIII pode-se notar que os resultados obtidos para os primeiros dez anos apresentam melhora de 12,4% no VPL acumulado, indicando que o investimento pode ter seu tempo de retorno do investimento reduzido. Para fins de comparação, a análise de viabilidade econômica na Tabela IX é realizada para os cinco primeiros anos utilizando-se os dados reais do IPCA desde o ano de 2016. Essa comparação permite afirmar que a estimação do IPCA por RNAs perceptron multi-camadas com seleção de atributos possibilita uma maior acurácia no cálculo do tempo de retorno do investimento de projetos de geração fotovoltaica.

### V. CONCLUSÃO

Este trabalho de conclusão de curso propôs a realização da análise de viabilidade econômica de projetos de geração fotovoltaica através da estimação do IPCA por RNAs perceptron multi-camadas com seleção de atributos.

A partir dos resultados obtidos, observa-se que a RNA perceptron multi-camadas tem um bom desempenho para estimar a série temporal do IPCA através de indicadores macroeconômicos prévios. Também é possível afirmar que as estimações do IPCA para os horizontes de cinco e dez anos apresentam resultados mais próximos dos valores reais do que as estimações para os horizontes de um e três anos.

Esse tipo de estimação se mostrou bastante relevante para a condução de estudos de análise de viabilidade econômica,

principalmente para a implementação de projetos cujo tempo de retorno do investimento seja longo.

A estimação do IPCA por uma RNA perceptron multi-camadas foi realizada com pequenos EQM e EAM. No entanto, para esta aplicação, recomenda-se um refinamento e estudo mais aprofundado das variáveis macroeconômicas que influenciam o cálculo do IPCA, além de outras técnicas que tornem a RNA perceptron multi-camadas mais estável em suas previsões. A tendência é que, com o passar dos anos, a base de dados dessas variáveis macroeconômicas se torne maior, o que contribuirá para um melhor aprendizado da RNA e, consequentemente, estimativas mais precisas.

### REFERÊNCIAS

- [1] R. J. Komp, "Practical photovoltaics," *Ann Arbor, MI: Aatec Publications*, 1995.
- [2] A. d. L. PUCCINI, *Matemática financeira e análise de investimentos*. Ed. Beta, 1977.
- [3] J. F. d. C. Carção, "Tarifas de energia elétrica no brasil." Ph.D. dissertation, Universidade de São Paulo, 2011.
- [4] R. T. Cusinato, "Ensaio sobre previsão de inflação e análise de dados em tempo real no brasil," 2009.
- [5] C. Zaniol, C. Pazinato, and J. Moraes, "Intervalos de confiança de núcleos de inflação utilizando wavelets e redes neurais," *Anais do X Encontro Regional de Matemática Aplicada e Computacional do Rio Grande do Sul-ERMACRS*, 2020.
- [6] L. Gavioli and I. Luna, "Estimando a taxa de inflação no brasil: comparação entre o modelo arima e o modelo de redes neurais multicamadas mlp," XIX Congresso Interno de Iniciação Científica - CNPq, Instituto de Economia - IE, Departamento de Teoria Econômica, UNICAMP, 2011.
- [7] I. Schroeder, C. Shinoda, and R. P. da Costa, "O custo de capital como taxa mínima de atratividade na avaliação de projetos de investimento," *Revista Gestão Industrial*, vol. 01, no. 02, pp. 033-042, 2005.

Tabela VIII

FLUXO DE CAIXA PARA O CÁLCULO DO TEMPO DE RETORNO DO INVESTIMENTO PELO MÉTODO DO VALOR PRESENTE LÍQUIDO CONSIDERANDO-SE A ESTIMAÇÃO DO IPCA POR RNAs COM SELEÇÃO DE ATRIBUTOS

Ano	Queda de Eficiência [R\$]	Economia [R\$]	Depreciação [R\$]	Valor Operacional [R\$]	VPL do Valor Operacional [R\$]	VPL Acumulado [R\$]	Coefficiente de Payback
1	100,0	59.391,36	80.852,24	-21.460,88	-20.409,30	-1.070.950,27	1
2	99,2	65.014,06	77.618,15	-12.604,09	-11.702,90	-1.082.653,17	1
3	98,4	71.164,44	74.384,06	-3.219,62	-3.020,65	-1.085.673,82	1
4	97,6	77.891,51	71.149,97	6.741,54	6.260,19	-1.079.413,62	1
5	96,8	85.248,74	67.915,88	17.332,86	15.906,37	-1.063.507,26	1
6	96,0	93.294,53	64.681,79	28.612,74	25.451,03	-1.038.056,22	1
7	95,2	102.092,60	61.447,70	40.644,89	38.653,29	-999.402,93	1
8	94,4	111.712,46	58.213,61	53.498,85	49.673,68	-949.729,25	1
9	93,6	122.230,00	54.979,52	67.250,48	63.094,40	-886.634,85	1
10	92,8	133.727,98	51.745,43	81.982,55	76.129,00	-810.505,85	1

Tabela IX

FLUXO DE CAIXA PARA O CÁLCULO DO TEMPO DE RETORNO DO INVESTIMENTO PELO MÉTODO DO VALOR PRESENTE LÍQUIDO CONSIDERANDO-SE O VALOR REAL DO IPCA DESDE O ANO DE 2016

Ano	Queda de Eficiência [R\$]	Economia [R\$]	Depreciação [R\$]	Valor Operacional [R\$]	VPL do Valor Operacional [R\$]	VPL Acumulado [R\$]	Coefficiente de Payback
1	100,0	59.391,36	80.852,24	-21.460,88	-20.110,99	-1.070.950,27	1
2	99,2	65.014,06	77.618,15	-12.604,09	-12.232,27	-1.083.182,54	1
3	98,4	71.164,44	74.384,06	-3.219,62	-3.098,88	-1.086.281,42	1
4	97,6	77.891,51	71.149,97	6.741,54	6.450,98	-1.079.830,44	1
5	96,8	85.248,74	67.915,88	17.332,86	16.549,41	-1.063.281,03	1

- [8] M. Stopatto, *Análise de Investimentos e Fontes de Financiamento*. Editora e Distribuidora Educacional S.A., 2016.
- [9] A. F. Carrara and A. L. Correa, "O regime de metas de inflação no brasil: uma análise empírica do ipca," *Revista de Economia Contemporânea*, vol. 16, pp. 441–462, 2012.
- [10] F. CARVALHO, F. d. SOUZA, J. SICSÚ, L. PAULA, and R. STUDART, "Economia monetária e financeira. rio de janeiro: Campus," 2007.
- [11] M. A. S. VASCONCELLOS and M. E. GARCIA, "Fundamentos de economia. 9ª tiragem," *São Paulo: Saraiva*, 2002.
- [12] M. A. Hall, "Correlation-based feature selection for machine learning," 1999.
- [13] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, and I. H. Witten, "The weka data mining software: an update," *ACM SIGKDD explorations newsletter*, vol. 11, no. 1, pp. 10–18, 2009.
- [14] S. Haykin, *Redes neurais: princípios e prática*. Bookman Editora, 2007.
- [15] A. P. d. L. CARVALHO, "Perceptron multi-camadas (mlp), disponível em: <https://sites.icmc.usp.br/andre/research/neural/mlp.htm>," Acesso em 28 de julho de 2021.
- [16] T. M. Leite, "Redes neurais, perceptron multicamadas e o algoritmo backpropagation, disponível em: <https://medium.com/ensina-ai/redes-neurais-perceptron-multicamadas-e-o-algoritmo-backpropagation-eaf89778f5b8>," Acesso em 28 de julho de 2021.
- [17] M. Minsky and S. Papert, "Perceptrons," mit press, cambridge, ma," 1969.
- [18] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *nature*, vol. 323, no. 6088, pp. 533–536, 1986.
- [19] M. da Mata Ribeiro and S. S. Quimaraes, "Redes neurais utilizando tensorflow e keras," *RE3C-Revista Eletrônica Científica de Ciência da Computação*, vol. 13, no. 1, 2018.
- [20] K. Knight, "Connectionist ideas and algorithms," *Communications of the ACM*, vol. 33, no. 11, pp. 58–74, 1990.
- [21] E. Rumelhart, G. Hinton, and R. Williams, "Learning internal representations by error propagation in parallel distributed processing mit press," 1986.
- [22] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [23] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The bulletin of mathematical biophysics*, vol. 5, no. 4, pp. 115–133, 1943.
- [24] K. Documentation, "Disponível em: <https://keras.io/>," Acesso em, vol. 22, 2018.
- [25] B. R. Tavano, "Geração de energia elétrica por sistemas fotovoltaicos: princípio de funcionamento e viabilidade técnica e econômica." Monografia (Bacharel Engenharia Elétrica ) Departamento de Engenharia Elétrica – Centro de Ciências Exatas e de Tecnologia, Universidade Federal de São Carlos, 2016.